

**PRIORITY
DOCUMENT**
SUBMITTED OR TRANSMITTED IN
COMPLIANCE WITH RULE 17.1(a) OR (b)



EPO - Munich
83
21. Jan. 2005

**Prioritätsbescheinigung über die Einreichung
einer Patentanmeldung**

REC'D 11 FEB 2005
WIPO PCT

Aktenzeichen:

10 2004 001 212.1

Anmeldetag:

06. Januar 2004

Anmelder/Inhaber:

Deutsche Thomson-Brandt GmbH,
78048 Villingen-Schwenningen/DE

Bezeichnung:

Verfahren und Vorrichtung zum Durchsuchen
einer Datenbank in zwei Suchschritten

IPC:

G 06 F 17/30

Die angehefteten Stücke sind eine richtige und genaue Wiedergabe der ursprünglichen Unterlagen dieser Patentanmeldung.

München, den 11. November 2004
Deutsches Patent- und Markenamt
Der Präsident
Im Auftrag

Klostermeyer

Verfahren und Vorrichtung zum Durchsuchen einer Datenbank in zwei Suchschritten

5

Die vorliegende Erfindung betrifft ein Verfahren zum Durchsuchen einer Datenbank auf einem Plattenspeichermedium, insbesondere einer CD-ROM oder DVD-ROM. Darüber hinaus betrifft die vorliegende Erfindung eine entsprechende Vorrichtung zum
10 Durchsuchen einer Datenbank.

Datenbanksysteme greifen üblicherweise auf einen festen oder dynamischen Datenbestand zu. Dieser Datenbestand ist in der Regel auf einer Festplatte abgelegt. Manchmal sind die Daten
15 auch in einem ROM gespeichert, wie dies bei T9-Sprachdatenbanken von Mobiltelefonen der Fall ist. Darüber hinaus ist bekannt, dass beispielsweise Telefonbücher auf CD- oder DVD-ROMs abgelegt werden.

20 Derzeit werden dynamische Datenbanken jedoch nicht auf optischen Medien gespeichert. Dies liegt an den verhältnismäßig großen Sprungzeiten der beschränkten Anzahl von Wiederbeschreibzyklen auf einem optischem Medium im Vergleich zu einer Festplatte. Komplexe Suchanfragen sind daher auf optischen Medien sehr zeitraubend.
25

Die Aufgabe der vorliegenden Erfindung besteht somit darin, die Durchsuche von Datenbanken, insbesondere auf optischen Medien, zu optimieren.

30

Erfindungsgemäß wird diese Aufgabe gelöst durch ein Verfahren zum Durchsuchen einer Datenbank auf einem Plattenspeichermedium durch Ausführen eines ersten Suchschritts, mit dem die gesamte Datenbank auf dem Plattenspeichermedium ges-
35 cannt wird, Bereitstellen eines Zwischenergebnisses aus dem ersten Suchschritt, Ausführen eines zweiten Suchschritts in

dem Zwischenergebnis des ersten Suchschritts und Bereitstellen eines Endergebnisses aus dem zweiten Suchschritt.

Ferner ist erfindungsgemäß vorgesehen eine Vorrichtung zum
5 Durchsuchen einer Datenbank auf einem Plattenspeichermedium mit einer Sucheinrichtung zum Ausführen eines ersten Suchschritts, mit dem die gesamte Datenbank auf dem Plattenspeichermedium scannbar ist, und einer Speichereinrichtung zum
10 Abspeichern und Bereitstellen eines Zwischenergebnisses aus dem ersten Suchschritt, wobei die Sucheinrichtung auch zum Ausführen eines zweiten Suchschritts in dem Zwischenergebnis des ersten Suchschritts und zum Bereitstellen eines Endergebnisses aus dem zweiten Suchschritt ausgebildet ist.

15 Der Erfindung liegt der Gedanke zu Grunde, dass für die Suche möglichst wenige Sprünge des Lesekopfs auf dem Plattenspeichermedium, insbesondere der optischen Platte, durchgeführt werden sollen. Auf diese Weise kann die Suchzeit deutlich minimiert werden, da für ausführliche Suchvorgänge zur
20 Verfeinerung des ersten Suchschritts nicht mehr auf die Platte zurückgegriffen werden muss, sondern ein Zugriff auf eine schnelle Speichereinrichtung möglich ist.

Vorzugsweise ist im ersten Suchschritt die Verarbeitungsgeschwindigkeit der Daten mindestens so hoch wie die Einlesegeschwindigkeit der Daten. Dies kann erreicht werden, indem die Suchtiefe an die Einlesegeschwindigkeit angepasst wird. Damit wird der Lesevorgang auf der Platte beim ersten Suchschritt nicht unterbrochen und ein zeitaufwändiger Rück-
30 sprung ist nicht notwendig.

In dem ersten Suchschritt kann ausschließlich eine Mustersuche (pattern match) durchgeführt werden. Die Mustersuche lässt sich sehr rasch ausführen im Gegensatz zu beispielsweise
35 rechenaufwändigen Vergleichsoperationen. Wird beim Suchen eine Index-Liste verwendet, so ist es vorteilhaft, wenn im ersten Suchschritt die Suchstellen ausschließlich nach

Sektornummern sortiert ab- oder aufsteigend angesprungen werden. Auch durch diese Maßnahme lässt sich die mittlere Sprungweite reduzieren.

5 Das Zwischenergebnis, das beim ersten Suchschritt erhalten wird, kann eine oder mehrere Teilergebnisse umfassen, die jeweils in dem zweiten Suchschritt durchsucht werden. Damit können beispielsweise durch den ersten Suchschritt einzelne Teilbäume geliefert werden, die im zweiten Suchschritt nach
10 speziellen Elementen durchforstet werden.

Bei einer bevorzugten Variante ist die Datenbank dynamisch und liegt fragmentiert vor, wobei die einzelnen Fragmente nacheinander eingelesen und Sprünge eines Lesekopfs ausschließlich in eine Richtung zwischen den Fragmenten durch-
15 geführt werden. Auf diese Weise wird ebenfalls vermieden, dass die Anzahl der Sprünge über ein notwendiges Minimum steigt. Insbesondere wird hierdurch auch die Sprungweite minimiert, da die Sprünge nur in einer Richtung vollzogen wer-
20 den.

Aus Sicherheitsgründen können die Daten auf dem Plattenspeichermedium in ECC-Blöcken (Error Correction Code) gespeichert werden. Um so wichtiger ist dann, dass die Anzahl der
25 Sprünge reduziert wird, da die ECC-Blöcke stets komplett gelesen werden müssen und ein Sprung auf der Platte in der Regel eine Nachbewegung zum Blockanfang erfordert.

Vorzugsweise handelt es sich, wie bereits angedeutet, bei
30 dem Plattenspeichermedium um eine optische Platte, wie eine CD oder DVD. Bei diesen optischen Platten, bei denen der Lesekopf im Verhältnis zu Festplatten sehr langsam bewegt wird, kann durch das erfindungsgemäße Verfahren der höchste Gewinn erwartet werden.

Die vorliegende Erfindung wird nun anhand der beigefügten Zeichnung näher erläutert, die eine Prinzipskizze des erfindungsgemäßen Verfahrens wiedergibt.

- 5 Das nachfolgend näher geschilderte Ausführungsbeispiel stellt eine bevorzugte Ausführungsform der vorliegenden Erfindung dar.

Eine vollständige Durchsuchung einer Datenbasis auf einer
10 Platte wird erfindungsgemäß dadurch erreicht, dass ein erster Prozess (Thread) eine vollständige Suche durch den Datenbestand leistet und dabei eine aus Sicht der Prozessorleistung einfache, grobe und schnelle Suche in einem ersten Suchschritt durchführt. Dabei wird der Datenbestand aus
15 Sicht der Sektornummerierung möglichst kontinuierlich auf der Platte durchsucht. Das spart langwierige Pick-up Sprünge des Laufwerks.

Jeder Suchtreffer wird dann an einen zweiten Suchschritt
20 weitergeleitet. Dies bedeutet, die in Frage kommenden Daten werden vom ersten Suchschritt an den zweiten Suchschritt, d.h. von dem ersten Prozess an einen parallel laufenden zweiten Prozess, übergeben. Der erste Suchschritt wartet nicht auf das Ergebnis des zweiten Suchschritts, d.h. er
25 setzt seine grobe Suche unmittelbar fort.

Der zweite Suchschritt ist zuständig für komplexere Suchaufgaben, wie z.B. Vergleiche, die eventuell mehr CPU Rechenleistung erfordern. Dieser Suchprozess wird dann unabhängig
30 von der groben Suche in dem separaten parallelen zweiten Prozess (Thread) durchgeführt.

Diese Aufteilung ist z.B. insbesondere für hierarchische und Text basierte Datenbanken interessant, wie z.B. XML Datenbanken. Eine Suchanfrage an solche Datenbanken besteht häufig
35 aus Text, Elementnamen und Attributnamen. Beispielsweise könnte die Suchanfrage lauten: Suche in einer Musikdatenbank

den Titel „Wonderful tonight“ von Eric Clapton. Der erste Suchschritt durchsucht dann in einem schnellen Text-Scan den gespeicherten Datenbestand. Im konkreten Beispiel wird die Musikdatenbank nach Treffern des Sängers „Eric Clapton“ und
5 Treffern zu dem Titel „Wonderful tonight“ durchsucht. Das ist eine Art von Suche, die nur begrenzte Rechenleistung erfordert. Die erforderliche Rechenleistung variiert, je nachdem wie fehlertolerant die Textsuche durchgeführt werden soll und ob z.B. unabhängig von Groß- oder Kleinschreibung
10 gesucht werden soll.

Letztendlich ist die zur Verfügung stehende Rechenleistung begrenzt. Sie wird ausgenutzt für einen groben, schnellen und kontinuierlichen Scan des Datenbestandes. Hierzu sei an-
15 gemerkt, dass eine optische Platte zwar im Vergleich zu einer Festplatte sehr lange braucht, um von einem Sektor zu einem anderen beliebigen Sektor auf der Platte zu springen (bis zu einer Sekunde), das kontinuierliche Einlesen von hintereinander liegenden Platten-Sektoren ist jedoch nur ge-
20 ringfügig langsamer als bei einer Festplatte. Folglich soll dieser kontinuierliche Scan des Datenbestandes möglichst weitgehend ausgenutzt werden. Voraussetzung hierfür ist, dass der grobe erste Suchschritt den Prozessor nicht überfordert. Dies wird erreicht, indem die CPU für die Verarbei-
25 tung im ersten Suchschritt nur wenig Zeit benötigt, so dass das Laufwerk bzw. Pick-up jeden Sektor des Datenbestandes sofort an den ersten Suchschritt abliefern kann. Andernfalls würde nämlich ein langwieriger Rücksprung des Pick-ups erzwungen werden.

30

Die grobe, erste Suche liefert daher wahrscheinliche Treffer, jedoch keine eindeutigen Treffer. Im konkreten Beispiel würden von dem ersten Suchschritt sämtliche Einträge in der Musikdatenbank mit „Eric Clapton“ und/oder „Wonderful to-
35 night“ als Treffer zur Verfügung gestellt werden. Dies bedeutet, dass auch andere Beiträge von Eric Clapton und andere Interpreten für das gesuchte Lied als Zwischenergebnis

festgehalten werden. Diese wahrscheinlichen Treffer werden direkt an einen zweiten unabhängigen Suchprozess weitergeleitet. Dieser zweite Suchprozess sorgt für die verfeinerte Suche, die dazu dient sicher zu stellen, dass es sich hierbei bei tatsächlich um einen Treffer handelt. In diesen Suchprozess erfolgt daher der Suchteil, der rechen technisch eine aufwändigere Suche realisiert, wie z.B. komplexe XPath Ausdrücke, wie sie für XML Datenbanken häufig Verwendung finden. In dem konkreten Beispiel wird in den Treffern für „Eric Clapton“ nach dem Stichwort „Wonderful tonight“ und umgekehrt gesucht. Als Endergebnis können damit Datenbankeinträge präsentiert werden, in denen sowohl der gesuchte Interpret als auch der gesuchte Titel auftreten.

Der Vorteil dieser zweistufigen Vorgehensweise besteht darin, dass ein vorselektierender Suchprozess, der möglichst wenig Rechenleistung erfordert, in einem Sprung reduzierten, kontinuierlichen Scan-Prozess den Datenbestand durchsucht. Dadurch erfolgt ein Scan des Datenbestandes mit maximaler Geschwindigkeit. Der zweite Suchprozess, der mit niedrigerer Priorität als der erste Suchprozess läuft, nutzt die restliche verbleibende Rechenleistung, um die letztendlichen Treffer zu lokalisieren.

Dieser Prozess liefert bereits Laufzeitvorteile bei fixen Datenbeständen auf CD-ROM und DVD-ROM. Er ist um so wirkungsvoller, wenn der Datenbestand fragmentiert auf der optischen Platte vorliegt. Das ist der Fall insbesondere bei dynamischen Datenbeständen.

30

Beispiel:

Der erste Suchschritt erlaubt die Suche nach XML Elementnamen, XML Attributnamen, XML Element Values (das ist Text) und XML Attribute Values (das ist auch Text) und XML Namespaces. Eine logische Verknüpfung zwischen gleichzeitig gesuchten Suchbausteinen, wie z.B. logische UND-Verknüpf-

ungen und logische ODER- Verknüpfungen, sind in diesem Beispiel auf Grund ausreichender Rechenleistung ebenfalls möglich. Dies bedeutet, dass die Suchtiefe im ersten Schritt von der zur Verfügung stehenden Rechenleistung abhängig ist.

5 Mit anderen Worten, in diesem Beispiel können bereits in Echtzeit, d.h. gleichzeitig während des Einlesens der Daten, Verknüpfungen von Einzeltreffern durchgeführt werden. Dies bedeutet wiederum, dass der erste Suchschritt bereits hierarchisch aufgebaut ist. Der erste Suchschritt liefert dann

10 Teilbäume zurück. Das sind z.B. Elemente, welche alle geforderten Elementnamen, Attributnamen und Value-Texte enthalten.

Im zweiten Schritt wird die Suche verfeinert, d.h. die komplexeren Suchanforderungen werden dort ausgeführt. Diese komplexeren Suchanforderungen sind beispielsweise die Reihenfolge von Elementen, Vergleichsoperationen und andere logische Abhängigkeiten, die vom ersten Suchschritt nicht getestet werden können.

20

Die Figur zeigt den parallelen Ablauf der Suche. Während der erste Suchschritt, symbolisiert durch einen kontinuierlichen Balken über der Zeit t , ununterbrochen den gesamten Datenbestand durchsucht, bekommt der zweite Suchschritt nur die

25 Treffer des ersten Suchschrittes geliefert. Die werden dann detailliert durchsucht. Die zweiten Suchschritte sind separate CPU Prozesse, die die restliche zur Verfügung stehende Rechenleistung nutzen. So wird der erste Suchschritt nicht gestört. Da der erste Suchschritt wegen der Eigenschaften

30 von optischen Platten i. a. der zeitaufwändigere Prozess ist stellt er den Flaschenhals dar. Bei dieser Prozessanordnung wird daher vermieden, dass der Prozess ins Stocken gerät, indem zeitaufwändige Untersuchungen aus diesem Prozess ausgelagert werden. Somit ist eine Suche bei vorgegebener Re-

35 chenleistung mit entsprechend maximaler Geschwindigkeit möglich.

Die Suchgeschwindigkeit kann ferner dadurch gesteigert werden, dass die zu durchsuchenden Daten möglichst in aufsteigender Sektorfolge auf dem optischen Medium abgelegt werden.

5 Die erfindungsgemäße Suche ist besonders dann von Vorteil, wenn keine Index-Listen für die Suche verwendet werden. Sind jedoch Index Listen vorhanden, dann ist eine Suche über den Index häufig sinnvoller. Sollten jedoch durch die Index-Liste verschiedene Stellen des Datenbestandes angesprungen
10 werden, so sollten die Ansprungpunkte aus der Index-Liste günstigerweise nach Sektornummern aufsteigend sortiert angesprungen und durchsucht werden, um im Mittel die Sprungzeiten zu reduzieren.

15 Da Index-Listen nur für spezielle Suchanfragen geeignet sind, wird praktisch jede Datenbank auf eine Komplettsuche für bestimmte komplexe Suchanfragen angewiesen sein, so dass die vorliegende Erfindung ebenso für jede Datenbank Anwendung finden kann.

20

Zusammenfassend lässt sich somit feststellen, dass der größte Nutzen der vorliegenden Erfindung bei Geräten mit optischen Laufwerken, die große Sprungzeiten aufweisen und schnelles Lesen zusammenhängender Sektoren ermöglichen, erzielt werden kann. Die großen Datenbestände auf diesen optischen Medien können dann bei begrenzter Rechenleistung mit sehr hoher Geschwindigkeit durchsucht werden. Durch kontinuierliches, Sektornummern aufsteigendes Lesen werden ECC-Blöcke (Error Correction Code) im Ganzen gelesen und alle
25 Datenbasis relevanten Sektoren gescannt. Die ECC-Blöcke bestehen bei DVDs aus 16 Sektoren à 2048 Bits und bei Blue-Ray-Platten aus 32 Sektoren à 2048 Bits. Diese Blöcke müssen komplett gelesen werden, um auch nur einen einzigen Sektor einsehen zu können. Hierzu ist bei Blue-Ray-Platten beispielsweise im inneren Radius etwa eine ganze Plattenumdrehung notwendig. Daher sollten willkürliche Sprünge über die
30
35

gesamte Platte die Ausnahme sein und können durch die vorliegende Erfindung im Wesentlichen vermieden werden.

Das erfindungsgemäße Prinzip ist natürlich auch für Datenbestände auf Festplatten geeignet. Dort ist der zu erwartende Vorteil aber gering, da die mittleren Sprungzeiten um mehrere Größenordnungen kürzer sind als bei optischen Platten. Außerdem werden auf einer Festplatte die Sektoren nicht in ECC Blöcken verpackt.

Patentansprüche

1. Verfahren zum Durchsuchen einer Datenbank auf einem Plattenspeichermedium
5 gekennzeichnet durch
 - Ausführen eines ersten Suchschritts, mit dem die gesamte Datenbank auf dem Plattenspeichermedium gescannt wird,
 - Bereitstellen eines Zwischenergebnisses aus dem ersten Suchschritt,
 - 10 - Ausführen eines zweiten Suchschritts in dem Zwischenergebnis des ersten Suchschritts und
 - Bereitstellen eines Endergebnisses aus dem zweiten Suchschritt.
- 15 2. Verfahren nach Anspruch 1, wobei in den ersten Suchschritt die Verarbeitungsgeschwindigkeit der Daten mindestens so hoch ist, wie die Einlesegeschwindigkeit der Daten.
- 20 3. Verfahren nach Anspruch 1 oder 2, wobei in dem ersten Suchschritt ausschließlich eine Textsuche durchgeführt wird.
- 25 4. Verfahren nach einem der vorhergehenden Ansprüche, wobei in dem ersten Suchschritt Suchstellen aus einer Index-Liste ausschließlich nach Sektornummern sortiert ab- oder aufsteigend angesprungen werden.
- 30 5. Verfahren nach einem der vorhergehenden Ansprüche, wobei das Zwischenergebnis ein oder mehrere Teilergebnisse umfasst, die jeweils in dem zweiten Suchschritt durchsucht werden.
- 35 6. Verfahren nach einem der vorhergehenden Ansprüche, wobei die Datenbank dynamisch ist und fragmentiert vorliegt und dabei die einzelnen Fragmente nacheinander eingelesen und

Sprünge eines Lesekopfs ausschließlich in einer Richtung zwischen den Fragmenten durchgeführt werden.

- 5 7. Verfahren nach einem der vorhergehenden Ansprüche, wobei die Daten auf dem Plattenspeichermedium in ECC-Blöcken gespeichert sind.
- 10 8. Verfahren nach einem der vorhergehenden Ansprüche, wobei das Plattenspeichermedium eine optische Platte ist.
9. Vorrichtung zum Durchsuchen einer Datenbank auf einem Plattenspeichermedium gekennzeichnet durch
- 15 - eine Sucheinrichtung zum Ausführen eines ersten Suchschritts, mit dem die gesamte Datenbank auf dem Plattenspeichermedium scannbar ist, und
 - einer Speichereinrichtung zum Abspeichern und Bereitstellen eines Zwischenergebnisses aus dem ersten Suchschritt, wobei
 - 20 - die Sucheinrichtung auch zum Ausführen eines zweiten Suchschritts in dem Zwischenergebnis des ersten Suchschritts und zum Bereitstellen eines Endergebnisses aus dem zweiten Suchschritt ausgebildet ist.
- 25 10. Vorrichtung nach Anspruch 9, wobei die Verarbeitungsgeschwindigkeit der Daten in der Sucheinrichtung in dem ersten Suchschritt mindestens so hoch ist, wie die maximale oder eine momentane Einlesegeschwindigkeit der Daten in die Sucheinrichtung.
- 30 11. Vorrichtung nach Anspruch 9 oder 10, wobei in der Sucheinrichtung bei dem ersten Suchschritt eine ausschließliche Textsuche durchführbar ist.
- 35 12. Vorrichtung nach einem der Ansprüche 9 bis 11, wobei in der Sucheinrichtung bei dem ersten Suchschritt Suchstel-

len aus einer Index-Liste ausschließlich nach Sektornummern sortiert ab- oder aufsteigend anspringbar sind.

13. Vorrichtung nach einem der Ansprüche 9 bis 12, wobei
5 das in der Speichereinrichtung speicherbare Zwischenergebnis ein oder mehrere Teilergebnisse umfasst, die von der Sucheinrichtung in dem zweiten Suchschritt durchsuchbar sind.
- 10 14. Vorrichtung nach einem der Ansprüche 9 bis 13, wobei die Datenbank dynamisch ist und fragmentiert vorliegt und dabei die einzelnen Fragmente in die Sucheinrichtung nacheinander einlesbar und Sprünge eines Lesekopfs ausschließlich in eine Richtung zwischen den Fragmenten aus-
15 führbar sind.
15. Vorrichtung nach einem der Ansprüche 9 bis 14, wobei die Sucheinrichtung und die Speichereinrichtung zur Verarbeitung von ECC-Blöcken geeignet ist.
20
16. Vorrichtung nach einem der Ansprüche 9 bis 15, wobei das Plattenspeichermedium eine optische Platte ist..
25

Zusammenfassung

Verfahren und Vorrichtung zum Durchsuchen einer Datenbank in zwei Suchschritten

5

Die Suche in Datenbeständen, insbesondere auf optischen Medien, soll hinsichtlich der für die Suche notwendigen Zeit optimiert werden. Daher wird vorgeschlagen, die Suche in zwei Schritten durchzuführen. In einem ersten Suchschritt wird die gesamte Datenbank auf dem Plattenspeichermedium gescannt. In einem parallel laufenden, zweiten Suchschritt werden Zwischenergebnisse des ersten Suchschritts durchsucht. Dadurch kann die Anzahl der Sprünge auf einer Platte reduziert werden, was insbesondere bei optischen Laufwerken zu Geschwindigkeitssteigerungen führt.

10

15

